

DOI: 10.19666/j.rlfed.202405129

基于动态记忆矩阵和加权多元状态估计的 电站辅机故障预警和定位方法

余兴刚¹, 王日成¹, 曾俊², 魏鑫³, 邱斌斌³

(1. 高效清洁发电技术湖南省重点实验室(国网湖南省电力有限公司电力科学研究院), 湖南 长沙 410017;

2. 湖南省湘电试验研究院有限公司, 湖南 长沙 410017;

3. 西安交通大学动力工程多相流国家重点实验室, 陕西 西安 710049)

[摘要] 电站辅机设备健康状态评估与故障预警对新型电力系统火电机组的安全运行具有重要意义。以某超临界 660 MW 火电机组送风机为研究对象, 提出了一种基于多重特征参数的送风机故障模型动态记忆矩阵构建方法, 该方法可在确保计算结果精度的同时有效提升模型计算速度。同时引入权重系数改进多元状态估计(multivariate state estimation technique, MSET)算法, 提出了一种权重系数计算方法: 采用总体相似度和参数相似度指标进行故障预警和定位, 构建了基于动态记忆矩阵和加权 MSET 算法的送风机故障预警模型。运用该模型对送风机故障进行仿真, 仿真结果表明: 加权 MSET 算法不仅能够有效提高故障工况下异常参数的预测精度, 还能降低异常参数对正常参数预测结果的影响, 进而在实现送风机故障提前预警的同时准确定位出故障点参数。

[关键词] 故障预警和定位; 动态记忆矩阵; 特征参数; 多元状态估计; 权重系数

[引用本文格式] 余兴刚, 王日成, 曾俊, 等. 基于动态记忆矩阵和加权多元状态估计的电站辅机故障预警和定位方法[J]. 热力发电, 2025, 54(3): 140-149. YU Xinggang, WANG Richeng, ZENG Jun, et al. Fault early warning and recognition of power plant auxiliary equipment based on dynamic memory matrix and weighted MSET[J]. Thermal Power Generation, 2025, 54(3): 140-149.

Fault early warning and recognition of power plant auxiliary equipment based on dynamic memory matrix and weighted MSET

YU Xinggang¹, WANG Richeng¹, ZENG Jun², WEI Xin³, QIU Binbin³

(1. Hunan Province Key Laboratory of Efficient & Clean Power Generation Technologies, (State Grid Hunan Electric Power Corporation Limited Research Institute), Changsha 410017, China;

2. Hunan Xiangdian Test & Research Institute Co., Ltd., Changsha 410017, China;

3. State Key Laboratory of Multiphase Flow in Power Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: It is of great significance to carry out health condition assessment and fault early warning of auxiliary equipment for safe operation of thermal power units in new power system. By taking the forced draft fan of a supercritical 660 MW thermal power unit as the research object, a method to construct dynamic memory matrix based on multiple characteristic parameters is proposed. The application shows that the proposed method can improve calculating speed of model effectively while ensuring the accuracy of calculated results. This work also presents a calculation method of weighted coefficients to modify the multivariate state estimation technique (MSET). The global similarity and parameter similarity indexes are introduced for fault early warning and recognition. An early fault warning model based on dynamic matrix and weighted MSET is utilized to simulate faults of forced draft fan. The results indicate that the weighted MSET model can not only improve the prediction accuracy of abnormal parameters under fault conditions effectively, but also reduce the influence of abnormal parameters on the predicted results of normal parameters. Consequently, the model proposed can realize both early

收稿日期: 2024-05-22 网络首发日期: 2024-11-21

基金项目: 国家重点研发计划资助(2022YFB4100700); 湖南省湘电试验研究院有限公司科技资助项目(XDKY-2021-08)

Supported by: National Key Research and Development Program (2022YFB4100700); Science and Technology Project of Hunan Xiangdian Test & Research Institute Co., Ltd. (XDKY-2021-08)

第一作者简介: 余兴刚(1989), 男, 博士, 高级工程师, 主要研究方向为火电机组热力性能分析及设备故障诊断, 849370151@qq.com.

warning of forced draft fan faults and recognition of abnormal parameters.

Key words: fault early warning and recognition; dynamic memory matrix; characteristic parameters; multivariate state estimation; weighted coefficients

在加快建设新型电力系统形势下, 煤电的地位已由传统的电力、电量主体电源转向基础保障性和系统调节性电源, 这对煤电机组的调节能力和设备可靠性提出了更高的要求^[1-3]。频繁的变负荷和长期低负荷运行, 会导致机组设备运行可靠性下降^[4-6]。对于煤电机组整个发电流程而言, 关键辅机与三大主机的作用同等重要, 然而辅机异常事故时常发生, 极大地制约了机组的灵活安全运行^[7]。煤电机组现有设计中, 辅机的异常状态监测大都通过设置固定的报警值和跳闸值实现, 侧重于事故后的应急处理, 难以实现故障的早期预警。现场人员在发现报警后进行干预和处理的时间十分有限, 容易造成设备的跳闸、损坏或机组非正常停运事故^[8-10]。

设备故障预警技术能够在故障发生前或故障发展的早期, 提前判断出设备有发生故障的倾向并发出预警信号, 可以有效防止设备跳闸或进一步损坏^[11]。设备故障预警方法主要有基于物理模型和数据驱动等方法, 由于电站辅机大都为复杂的动态对象, 建立其准确的物理模型难度极大^[12-16]。

目前, 众多学者采用数据驱动分析方法对电站辅机故障预警技术进行了深入的研究。周浩豪等^[17]提出了一种基于 SSAPSO-LightGBM 的设备故障预警算法并用于引风机轴承温度预测, 实现了引风机轴承故障的早期预警。杨婷婷等^[18]提出了一种基于卷积神经网络-长短时记忆神经网络 (CNN-LSTM) 的磨煤机故障预警方法, 并应用于磨煤机堵煤故障的预警。赵征等^[19]提出了一种基于深度双向门控循环神经网络的制粉系统状态估计和故障预警方法, 该方法充分学习时间序列的特征信息, 提高了模型在变工况时的预测精度。李刚等^[20]采用改进的自联想核回归 (auto associative kernel regression, AAKR) 算法建立了一次风机的故障预警模型, 通过将稳健距离算子代替马氏距离算子, 提高了 AAKR 模型的稳健性和抗污染能力。刘双白等^[21]提出了一种基于加权 AAKR 算法的风机故障预警模型, 通过引入权重系数使模型在异常工况下具有更好的残差污染抑制能力。牛玉广等^[22]采用多元状态估计技术 (multivariate state estimation technique, MSET) 与自适应阈值方法构建了磨煤机故障预警模型。蔡吉磊等^[23]采用改进层次凝聚聚类和 MSET 构建了给

水泵故障预警模型。余兴刚等^[24]采用动态记忆矩阵和 MSET 搭建了一次风机故障预警模型, 并通过引入参数误差分量指标进行故障点追溯。张凤丽等^[25]运用 K 均值聚类和 MSET 构建了热交换器的故障预警模型, 提出通过统计各参数实时偏差贡献率来锁定异常参数。

本文运用 MSET 算法对电站辅机故障预警和定位问题进行研究, 以某超临界 660 MW 燃煤发电机组送风机为研究对象, 提出了一种基于多重特征参数的动态记忆矩阵构建方法; 针对 MSET 算法在设备异常工况下抗污染能力差的问题, 引入权重系数构造加权 MSET 算法, 提高了异常工况下各参数的估计精度; 基于加权 MSET 算法对各参数的估计值与实测值的残差计算总体相似度和参数相似度, 实现了送风机故障的提前预警和故障参数的定位。

1 多元状态估计技术

多元状态估计技术是一种非线性、非参数的数据驱动建模方法, 最早由美国阿贡国家实验室开发并应用于核电厂设备和传感器的状态监测^[26-27]。算法基于设备正常运行状态的数据进行建模, 不需要难以获取的故障数据, 且与人工神经网络方法相比更容易实现多变量状态监测, 没有参数的训练过程以及需要预先设置的参数, 泛化精度高, 被广泛应用于许多工业领域设备的状态监测^[28]。

MSET 算法建模的关键之一为构建记忆矩阵 D 。假设某设备共有 n 个表征运行状态的监测参数, 在某一时刻 t 观测到的 n 个变量, 记为该设备的状态向量, 则有 $\mathbf{X}(t)=[x_1(t), x_2(t), \dots, x_n(t)]^T$ 。选取设备在正常运行区间内不同工况下采集的 m 个历史状态向量, 构成维度为 $n \times m$ 的记忆矩阵 D 。

$$D_{n \times m} = [\mathbf{X}(t_1), \mathbf{X}(t_2), \dots, \mathbf{X}(t_m)] = \begin{bmatrix} x_1(t_1) & x_1(t_2) & \dots & x_1(t_m) \\ x_2(t_1) & x_2(t_2) & \dots & x_2(t_m) \\ \vdots & \vdots & \dots & \vdots \\ x_n(t_1) & x_n(t_2) & \dots & x_n(t_m) \end{bmatrix} \quad (1)$$

对于输入的每一个观测向量 \mathbf{X}_{obs} , MSET 将其与记忆矩阵 D 进行相似性比较, 得到相应的权值向量 \mathbf{W} , 用以描述观测向量与记忆矩阵中各向量的相似程度, 计算记忆矩阵和权值向量的乘积即可获得表征设备正常运行状态的估计向量 \mathbf{X}_{est} 。

$$\mathbf{W} = [w_1, w_2, \dots, w_m]^T \quad (2)$$

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot \mathbf{W} = w_1 \mathbf{X}(t_1) + w_2 \mathbf{X}(t_2) + \dots + w_m \mathbf{X}(t_m) \quad (3)$$

假设观测向量和估计向量的残差向量为 $\boldsymbol{\varepsilon}$ ，在 $\|\boldsymbol{\varepsilon}\|_2$ 的最小化约束条件下，可推导得到权值向量的计算式如下：

$$\mathbf{W} = (\mathbf{D}^T \cdot \mathbf{D})^{-1} \cdot (\mathbf{D}^T \cdot \mathbf{X}_{\text{obs}}) \quad (4)$$

考虑到记忆矩阵 \mathbf{D} 的性质可能导致矩阵 $\mathbf{D}^T \cdot \mathbf{D}$ 不可逆，使式(4)不可求解。为解决该问题，MSET 算法使用非线性运算符 \otimes 代替矩阵乘法运算符。非线性运算符有多种类型，如高斯核函数、欧氏距离等。欧氏距离由于没有引入额外的超参数而得到广泛运用。欧氏距离计算式如下：

$$\otimes(\mathbf{X}, \mathbf{Y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

式中： x_i 为状态向量 \mathbf{X} 的第 i 个参数， y_i 为状态向量 \mathbf{Y} 的第 i 个参数。

确定非线性运算符的型式后，将权值向量计算式(4)代入式(3)后，可得到估计向量的计算式：

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (6)$$

此外，由于设备各监测参数的量纲一般不同，且数值也可能存在量级上的差别，若不做处理的话会影响权值因子的计算结果。本文采用 z -score 标准化对原始数据进行标准化处理，计算式如下：

$$x_z = \frac{x_i - \mu_i}{\sigma_i} \quad (7)$$

式中： μ_i 为参数的均值； σ_i 为参数的标准差； x_i 标准化前的值； x_z 为标准化后的值。

2 动态记忆矩阵构建方法

记忆矩阵的构建是 MSET 算法建模的关键步骤，直接决定了模型预测结果的精度^[29]。记忆矩阵在构建时应遵循在确保覆盖设备所有正常运行工况的前提下尽可能减小记忆矩阵中向量数量的原则。现有文献中用于构建记忆矩阵的方法主要有等距抽样法和聚类法^[13,22]。聚类法通过从大量的历史运行数据中提取能够代表设备各典型工况的状态向量，将聚类得到的类中心集合作为记忆矩阵，该方法无法充分利用人工经验的优势，且易排除掉样本量较少的正常状态点^[22]。等距抽样法可分为按照各变量均分抽样和按照各向量空间距离均分抽样。若按照所有变量进行均分抽样，当变量数量过多时会导致记忆矩阵的规模过大；由于空间距离计算时涉及状态向量中的所

有变量，但各变量的变化趋通常并不一致，可能导致所构建的记忆矩阵无法覆盖部分运行工况。

2.1 建模变量的选取

鉴于以上分析，本文提出了一种基于设备多重特征参数的记忆矩阵构建方法，采用某超临界 660 MW 火电机组配备的动叶可调轴流式送风机为研究对象对记忆矩阵构建方法进行说明。该送风机的主要监测参数见表 1。

表 1 送风机主要监测参数
Tab.1 Main monitoring parameters of the forced draft fan

编号	项目	单位
1	送风机电机电流	A
2	送风机入口风温	℃
3	送风机动叶开度	%
4	送风机出口风压	kPa
5	送风机润滑油压	MPa
6	送风机润滑油温	℃
7	送风机轴承温度 1~9	℃
8	送风机电机前/后轴承温度	℃
9	送风机轴承 X/Y 向振动	mm/s

表 1 中，电机电流表征送风机功率大小；入口风温表征送风机运行环境边界条件；动叶开度和出口风压表征送风机热力运行状态；润滑油压和油温为送风机轴承的运行边界条件，由润滑油系统的运行状况决定；轴承温度和振动则表征送风机及电机的机械运行状态，与送风机功率、热力运行状态和运行边界条件等息息相关。部分文献在表征电站辅机运行状态时常加上机组发电机功率^[22,24,30]，且将机组功率作为主参数，笔者认为这种处理方式并不合适，主要原因为：1) 每台火电机组通常配置 2 台送风机，且一般采用 2 台送风机并列运行的方式，若 1 台送风机因故障停运后，机组仍可带部分负荷运行，然而此时送风机运行状态与机组功率的关系和 2 台送风机并列运行时截然不同，容易使模型误报；2) 机组所燃用的煤种、煤质和环境温度经常发生变化，相同功率下对应的二次风量也会随煤种、煤质和环境温度的变化而变化。

为降低 MSET 算法的计算量，现有文献大多倾向于采用主成分或相关性分析方法对设备状态向量进行降维处理^[22-24]，这样处理后可以在保留设备大部分状态信息的同时有效降低模型计算量，但也会导致无法对设备的部分故障进行监测。因为某些参数可能在正常运行过程中具有一定的相关性，但在异常状态下这种关系可能会发生变化。

因此,本文在选取送风机的建模变量时,剔除部分冗余测点外,与送风机运行状态相关的表1中所有监测参数均参与建模。

2.2 历史正常状态集合的构建

根据送风机的运行特点,从监测参数中选取电机电流、入口风温、动叶开度、出口风压、润滑油压和润滑油温6个参数作为送风机的特征参数。先基于各特征参数从历史正常运行数据库中筛选部分状态向量构成历史正常状态集合,此集合中向量的数量通常较大,但能够覆盖送风机的所有正常运行工况,主要用于后续动态记忆矩阵的构建。历史正常状态集合的构建方法如下。

1) 在构建历史正常状态集合时,将送风机电机电流作为主特征参数。获取历史正常运行数据库中电机电流的最大值 I_{\max} 和最小值 I_{\min} ,按照步长 $(I_{\max}-I_{\min})/j$ 将历史正常运行数据库划分为 j 组。

2) 考虑到相同的电机电流下,其余特征参数的数值会随着运行工况和边界条件的变化而变化。针对步骤1)根据电机电流划分的每组数据,继续采用其余每个特征参数进行等距抽样。以送风机入口风温为例,等距抽样方法为:获取每组数据中入口风温的最大值 T_{\max} 和最小值 T_{\min} ,按照步长 $(T_{\max}-T_{\min})/k$,从每组数据中选取 k 个向量添加至历史正常状态集合中。

3) 去除历史正常状态集合中的重复向量。选取该超临界660 MW机组A送风机2019年11月至2020年9月的正常运行数据,基本涵盖了机组不同季节、不同负荷的运行工况。经剔除异常值和空值处理后剩余共计20 273组数据构成历史正常运行数据库,采用上述方法构建的历史正常状态集合共包含9 234组运行数据。

2.3 动态记忆矩阵的构建

按特征参数筛选的历史正常状态集合中所包含的向量数量仍然较大,若直接用于计算,必然会因计算量过大而降低模型的实时性。为提升模型计算速度,现有文献主要从降低记忆矩阵中状态向量的维度和数量着手,而降低状态向量的维度将会导致无法监测设备的部分故障。文献[22]根据机组功率将磨煤机的记忆矩阵分成3类,针对每一个功率区间分别构造一个记忆矩阵,以此来降低用于计算的记忆矩阵数量;但相同功率下磨煤机通常存在不同的运行方式组合,使机组功率与磨煤机运行状态的对应关系发生变化,会影响模型预测结果的精

度。文献[31]根据给煤量的大小将记忆矩阵划分为3类,并构建了3个磨煤机故障预警子模型,以提升模型计算速度。文献[29]提出了一种基于 k 最近邻的动态记忆矩阵构建方法,对于每个观测向量,先计算其与历史训练集中各向量的距离,选择与输入观测向量距离最近的 k 个向量构成动态记忆矩阵;这种方法不仅会引入额外的计算量,而且对于部分参数异常的工况,可能会导致无法选取到有效的历史状态向量。

笔者提出了一种基于多重特征参数的动态记忆构建方法,具体构建方法如下。

1) 获取送风机输入观测向量中各特征参数的数值,分别根据各特征参数值的正负一定范围从历史正常状态集合中筛选出相关状态向量构成集合 D_1-D_6 。

2) 将数据集合 D_1-D_6 中的向量合并、去除重复向量后构成新的向量集合 K ,分别计算集合 K 中每个向量在集合 D_1-D_6 中出现的次数。

3) 选取出现次数为6的向量添加至动态记忆矩阵中,若此时动态记忆矩阵中向量的数量大于一定值 z ,则停止选取;否则继续选取出现次数为5的向量加入动态记忆矩阵中,以此类推,直至动态记忆中向量的数量大于 z 。

采用上述方法构建动态记忆矩阵时,若各特征参数均正常,一般出现次数为6的向量数量即可满足动态记忆矩阵数量的要求。当个别特征参数出现异常时,亦可根据其余正常特征参数构建有效的动态记忆矩阵,确保模型的预测工作正常进行,提高MSET模型的适应性。

3 模型有效性验证

3.1 正常运行工况的预测结果

选取该送风机历史正常运行数据库中除历史正常状态集合外的共计11 039组数据构成验证集,使用上述MSET算法计算得到了验证集中各向量的估计向量,各参数估计值与实测值的相对误差见表2。相对误差的计算式为式(8)。图1为表2中平均相对误差较大的送风机出口风压、动叶开度和入口风温3个参数的相对误差变化趋势。


$$\delta_i = \left| \frac{x_{i,\text{obs}} - x_{i,\text{est}}}{x_{i,\text{obs}}} \right| \times 100\% \quad (8)$$

式中: $x_{i,\text{obs}}$ 为观测向量的第 i 个参数; $x_{i,\text{est}}$ 为估计向量的第 i 个参数。


表 2 验证集各参数的平均相对误差

Tab.2 The mean relative deviation of each parameter of the validation set


项目	相对误差/%
送风机电机电流	0.136
送风机入口风温	0.180
送风机动叶开度	0.218
送风机出口风压	0.236
送风机润滑油压	0.019
送风机润滑油温	0.116
送风机轴承温度 1	0.021
送风机轴承温度 2	0.034
送风机轴承温度 3	0.045
送风机轴承温度 4	0.020
送风机轴承温度 5	0.035
送风机轴承温度 6	0.047
送风机轴承温度 7	0.025
送风机轴承温度 8	0.036
送风机轴承温度 9	0.051
送风机电机前轴承温度	0.103
送风机电机后轴承温度	0.158
送风机轴承 X 向振动	0.053
送风机轴承 Y 向振动	0.076



a) 送风机出口风压



b) 送风机动叶开度



c) 送风机入口风温


图 1 验证集各参数相对误差的变化趋势

Fig.1 Change trends of relative deviations of the parameters in validation set


对于验证集中所有向量，各观测向量对应的动态记忆矩阵中向量的数量基本都在 1 000 以下，远小于历史正常状态集合中向量数量（9 234）。从图 1 和表 2 可以看出，基于动态记忆矩阵构建的 MSET 模型预测误差很小，各参数估计值与实测值的平均相对误差均小于 0.3%，且最大相对误差均在 2% 以内。可见，所提出的动态记忆矩阵构建方法可在降低记忆矩阵规模的同时，确保模型预测结果的精度满足工程应用的要求。

3.2 异常工况的预测结果


从该送风机验证集中随机选取 300 组向量，通过人为使参数发生阶跃变化模拟送风机的异常运行状态。以送风机动叶开度为例，从第 151 组样本开始，人为使送风机动叶开度的数值变为原来正常值的 2 倍，构成送风机动叶开度异常工况测试集，使用上述 MSET 模型对测试集进行计算，异常工况下送风机动叶开度、出口风压和电机电流预测结果与实测值的对比如图 2 所示。



a) 送风机动叶开度



b) 送风机出口风压



c) 送风机电机电流

图 2 异常工况下 MSET 算法的预测结果

Fig.2 The predicted results of abnormal condition using MSET

从图2可见,当对送风机动叶开度施加阶跃扰动后, MSET 模型预测得到的动叶开度值介于阶跃变化前、后值之间,与正常应达值(阶跃变化前的值)存在较大的偏差,若将模型估计值作为正常应达值进行故障诊断,会影响现场人员对故障程度的判断。此外,送风机动叶开度异常后,还会影响出口风压和电机电流的估计值,导致这2个参数的预测结果与实测值之间也出现较大偏差,会影响使用人员定位故障参数。

4 加权 MSET 算法

为解决 MSET 模型在异常工况下无法直接根据预测结果定位故障点的问题,文献[24-25]提出了采用参数误差分量或偏差贡献率指标来确定故障参数,但笔者认为该方法较为抽象、不直观,且容易导致漏判或误判。文献[20]提出了一种采用绝对值距离替代马氏距离的 AAKR 改进方法,笔者尝试采用不同的距离算子替代式(5)中的欧氏距离算子,未发现有明显的改善效果。文献[21,32]提供了一种通过引入权重系数的 AAKR 算法改进方法,其核心思想为:针对异常工况,通过对偏差较小的参数设置较大的权值,而对偏差较大的参数则赋予较小的权值,以此达到降低异常参数对预测结果影响的目的;但现有文献中鲜见报道关于 MSET 算法的类似改进方法。

本文结合 MSET 算法的特点,提出了一种 MSET 算法改进方法,具体如下。

1) 使用常规 MSET 模型对观测向量进行预测,得到观测向量的估计向量;

2) 根据观测向量和估计向量中各参数的偏差分别计算各参数的权重系数,并将权重系数代入式(5)对非线性运算符进行改进,改进后非线性运算符计算公式为:

$$\otimes(\mathbf{X}, \mathbf{Y}) = \sqrt{\sum_{i=1}^n w_i (x_i - y_i)^2} \quad (9)$$

式中: w_i 为第 i 个参数的权重系数。

在选取权重系数计算方法时,需要遵循参数的估计值和实测值偏差越大、权重值越小的原则,且需兼顾各参数的数据分布特性。此外,为防止参数的权重值过大或过小,还应对权重值的取值范围进行限制。经过分析、比较,本文权重系数计算式为:

$$w_i = \frac{f_i^2}{f_1^2 + f_2^2 + \dots + f_n^2} \quad (10)$$

$$f_i = \exp\left(-\left|\frac{x_{i,obs} - x_{i,est}}{\sigma_i}\right|\right) \quad (11)$$

式中: $x_{i,est}$ 为采用常规 MSET 算法预测得到的第 i 个参数的估计值; $x_{i,obs}$ 为第 i 个参数的实测值。

式(10)可确保各参数的权重值之和为1,且能够将参数权重值的取值范围限制在[0, 1];式(11)通过引入参数的标准差来考虑其数据分布特性,对于数据分布集中即标准差较小的参数,权重系数对偏差的变化更为敏感。

3) 再次使用加权 MSET 算法对观测向量进行计算,并将预测结果输出作为最终预测结果。

以 3.2 节送风机动叶开度异常工况测试集为例,采用加权 MSET 算法对该异常工况进行仿真,图3为异常工况下送风机动叶开度、出口风压和电机电流加权 MSET 算法预测结果与实测值对比。




图3 异常工况下加权 MSET 算法的预测结果
Fig.3 The predicted results of abnormal condition using weighted MSET

对比图2和图3可以看出,对于正常的前150组数据,2种算法预测精度均较高;但对于施加动

叶开度阶扰动后的异常数据, 加权 MSET 算法预测得到的动叶开度应达值与阶跃变化前的值基本一致, 而且出口风压和电机电流的估计值与实测值之间的偏差也较小, 有利于实现设备故障程度的准确评估和故障参数的精准定位。

对于上述异常工况, 尽管异常参数动叶开度为送风机的特征参数, 但加权 MSET 算法依然能够给出准确的预测结果, 这表明 2.3 节提出的动态记忆矩阵构建方法可以适应特征参数异常的工况。

5 故障预警及定位

5.1 故障预警方法

通过加权 MSET 算法计算得到观测向量的估计向量后, 各参数的实测值和估计值之间正常会存在着不同程度的偏差, 分析各参数的偏差可以对设备的运行状态进行评估。本文将以观测向量和估计向量之间欧氏距离为基础的相似度定义为总体相似度来对设备整体运行状态进行评价, 将以各参数绝对偏差为基础的相似度定义为参数相似度来确定设备故障参数。总体相似度计算式为:

$$S_t = \frac{1}{1 + \sqrt{\sum_{i=1}^n (x_{i,obs} - x_{i,est})^2}} \quad (12)$$

参数相似度的计算式为:

$$S_i = \frac{1}{1 + |x_{i,obs} - x_{i,est}|} \quad (13)$$

相似度的取值范围为[0,1], 数值越接近 1, 说明观测向量与估计向量越相似或参数的观测值与估计值之间偏差越小。

设备在正常运行过程中, 各测点经常会因受到某些不确定因素和随机干扰等的影响而存在不同程度的波动。为降低这种波动导致的误报警, 采用滑动窗口法对相似度序列进行平均值滤波。假设某段时间内, 相似度序列为:

$$S = [S_1, S_2, \dots, S_N, \dots, S_m] \quad (14)$$

假设滑动窗口宽度为 N , 对窗口内连续的 N 个相似度计算平均值作为最终输出结果:

$$\bar{S} = \frac{1}{N} \sum_{i=1}^N S_i \quad (15)$$

为提高故障预警的可靠性, 采用验证集数据确定设备故障预警阈值, 预警阈值计算公式为:

$$S_y = \frac{S_{\min}}{k} \quad (16)$$

式中: S_y 为预警阈值; S_{\min} 为验证集数据相似度的

最小值; k 为预警阈值系数, 根据现场运行经验确定, 一般不小于 1。

当设备的整体相似度低于预警阈值时, 说明设备可能存在异常, 发出故障预警信号。当某参数的相似度低于其预警阈值时, 说明该参数可能为故障参数, 现场人员可进一步对该参数进行分析确定故障程度和类型并采取处理措施。

5.2 设备故障预警仿真

以该超临界 660 MW 机组送风机为例, 从验证集中选取 300 组轴承温度变化不大的样本, 并从第 101 组样本开始人为给轴承温度 1 测点增加步长为 0.1 °C 的累计偏移量, 构成送风机轴承温度高故障测试集。采用常规 MSET 模型和所提出的加权 MSET 模型分别对该异常工况进行仿真, 2 种模型计算得到的送风机轴承温度 1 和出口风压与实测值的对比如图 4 所示。

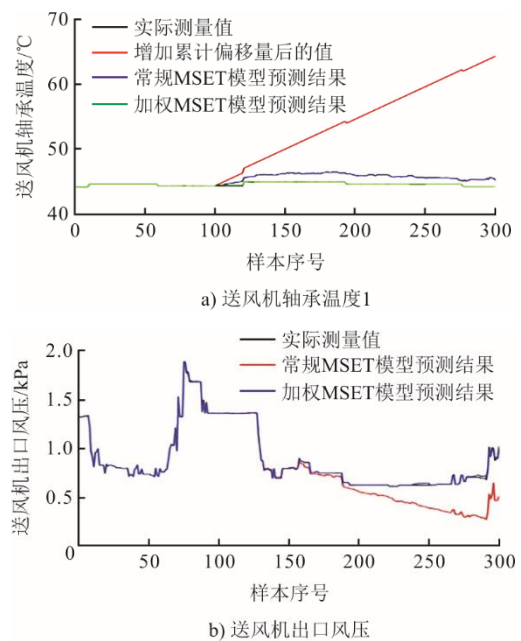


图4 轴承温度高故障工况预测结果与实测值的对比
Fig.4 The predicted values and measured values for high bearing temperature fault

从图4可以看出, 对于未加偏移量的前 100 组样本, 常规 MSET 模型和加权 MSET 模型预测得到的送风机轴承温度 1 和出口风压与实测值基本一致, 这表明 2 种模型对于正常运行工况均具有较高的预测精度。但对于加累计偏移量的后 200 组样本, 常规 MSET 模型预测得到的轴承温度 1 与应达值 (未施加累计偏移量的值) 存在一定的偏差; 此外, 当轴承温度 1 偏移量增大至一定值后, 常规 MSET 模型预测得到的出口风压也与实测值产生了较大

的偏差,且随着轴承温度1累计偏移量的增加而逐渐增大。在第300组样本处,常规MSET模型对于轴承温度1和出口风压预测结果的相对误差分别为29.7%和51.3%,其中轴承温度1的相对误差根据模型估计值和加累计偏移量后的值计算得到,若根据这一预测结果确定故障参数,会导致误将异常参数定位为出口风压。而加权MSET模型预测得到的后200组样本轴承温度1和出口风压数值与对应的应达值之间的偏差则较小,可避免模型出现误诊断。

对于该轴承温度高异常工况,根据加权MSET模型的预测结果,经滑动窗口法处理后的送风机总体相似度和轴承温度1的相似度变化曲线如图5和图6所示。图5和图6中送风机总体相似度和轴承温度1相似度的预警阈值系数 k 均取为1.3。




图5 送风机总体相似度

Fig.5 The predicted global similarity of forced draft fan




图6 送风机轴承温度1相似度

Fig.6 The predicted similarity of bearing temperature 1 of forced draft fan

由图5和图6可见,随着送风机轴承温度1累计偏移量的逐渐增大,总体相似度和轴承温度1的相似度均逐渐下降,总体相似度在第130个样本点首次降至预警阈值以下,轴承温度1的相似度则在第116个样本点首次降至预警阈值以下,2个评价指标的报警点存在一定差异。这主要是因为验证集总体相似度的最小值受设备所有监测参数预测结果误差的累计影响,导致总体相似度和轴承温度1相似度的预警阈值不同。但这并不影响模型故障预警和定位功能的实现,通过对图5总体相似度的监视可以实现送风机异常状态的提前预警,而对图6

参数相似度的监视可定位出故障参数为送风机轴承温度1。

此外,图5中总体相似度报警处送风机轴承温度1为48℃,而DCS中该测点设置报警值为90℃。可见,该故障预警模型可在送风机轴承性能下降早期即给出预警信号,为现场人员处理故障提供充足时间,可有效避免送风机的进一步损坏。

6 结 论

1) 以某超临界660 MW火电机组送风机为研究对象,运用MSET算法构建了送风机故障预警模型,提出了一种基于多重特征参数的动态记忆矩阵构建方法,该方法不仅能够确保记忆矩阵对送风机历史正常运行工况的全覆盖,还可大幅度地降低记忆矩阵规模,提高模型的计算速度。

2) 针对MSET算法在异常工况下预测结果精度差的问题,引入权重系数构建了加权MSET算法,实例仿真结果显示加权MSET算法在故障工况下具有较强的稳健性和抗污染能力。

3) 基于加权MSET算法的预测结果,引入总体相似度和参数相似度指标进行故障预警和定位,结果表明模型能够实现故障的提前预警,并可准确定位出故障参数。

[参 考 文 献]

- [1] 尹积军, 吴文传. 浙江构建新型电力系统的技术路径与实践[J]. 中国电机工程学报, 2023, 43(14): 5404-5415.
YIN Jijun, WU Wenchuan. Technical path and practice for constructing the new-type power system in Zhejiang province[J]. Proceedings of the CSEE, 2023, 43(14): 5404-5415.
- [2] 钟伟, 周宇杰, 王泽焯, 等. 新型电力系统安全稳定运行分析[J]. 湖南电力, 2022, 42(3): 29-34.
ZHONG Wei, ZHOU Yujie, WANG Zeyu, et al. Analysis of safe and stable operation of new power system[J]. Hunan Electric Power, 2022, 42(3): 29-34.
- [3] 张智刚, 康重庆. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 2022, 42(8): 2806-2818.
ZHANG Zhigang, KANG Chongqing. Challenges and prospects for constructing the new-type power system towards a carbon neutrality future[J]. Proceedings of the CSEE, 2022, 42(8): 2806-2818.
- [4] 欧阳子区, 王宏帅, 吕清刚, 等. 煤粉锅炉发电机组深度调峰技术进展[J]. 中国电机工程学报, 2023, 43(22): 8772-8790.
OUYANG Ziqu, WANG Hongshuai, LYU Qinggang, et al. Research progress on deep peak shaving technology of pulverized coal-fired boiler power unit[J]. Proceedings of the CSEE, 2023, 43(22): 8772-8790.
- [5] 王锡辉, 朱晓星, 陈厚涛, 等. 燃煤机组辅机设备运行

- 健康状态在线评估方法及应用[J]. 中国电机过程学报, 2022, 42(7): 2597-2605.
WANG Xihui, ZHU Xiaoxing, CHEN Houtao, et al. Application of an online evaluation method for operating health status of auxiliary equipment in coal-fired power plants[J]. Proceedings of the CSEE, 2022, 42(7): 2597-2605.
- [6] 杨倩鹏, 林伟杰, 王月明, 等. 火力发电产业发展与前沿技术路线[J]. 中国电机工程学报, 2017, 37(13): 3787-3794.
YANG Qianpeng, LIN Weijie, WANG Yueming, et al. Industry development and frontier technology roadmap of thermal power generation[J]. Proceedings of the CSEE, 2017, 37(13): 3787-3794.
- [7] 吕当振, 宾谊沅, 李文军, 等. 600 MW 超临界机组锅炉轴流风机并列与过程控制技术[J]. 中国电机工程学报, 2020, 40(17): 5574-5582.
LYU Dangzhen, BIN Yiyuan, LI Wenjun, et al. The parallel and process of control technology of axial flow fans in a 600 MW supercritical boiler[J]. Proceedings of the CSEE, 2020, 40(17): 5574-5582.
- [8] 孙建平, 赵立慧, 孙博扬, 等. 基于数据驱动与多变量状态估计的汽动引风机故障预警[J]. 热力发电, 2020, 49(1): 78-84.
SUN Jianping, ZHAO Lihui, SUN Boyang, et al. Early warning of steam-driven induced draft fan based on data-driven and MSET[J]. Thermal Power Generation, 2020, 49(1): 78-84.
- [9] 孙建平, 高明. 改进“峰”方法的多元状态估计技术用于电站风机状态监测[J]. 华北电力大学学报(自然科学版), 2013(3): 91-94.
SUN Jianping, GAO Ming. Condition monitoring of fan in power plant using multivariate state estimation technique of modified mountain method[J]. Journal of North China Electric Power University, 2013(3): 91-94.
- [10] CAESARENDRA W, LEE J M, HA J M, et al. Slew bearing early damage detection based on multivariate state estimation technique and sequential probability ratio test[C]. IEEE International Conference on Advanced Intelligent Mechatronics. Busan: IEEE, 2015: 1161-1166.
- [11] 刘吉臻, 胡勇, 曾德良, 等. 智能发电厂的架构及特征[J]. 中国电机工程学报, 2017, 37(22): 6463-6470.
LIU Jizhen, HU Yong, ZENG Deliang, et al. Architecture and feature of smart power generation[J]. Proceedings of the CSEE, 2017, 37(22): 6463-6470.
- [12] LI W, PENG M J, YANG M, et al. Design of comprehensive diagnosis system in nuclear power plant[J]. Annals of Nuclear Energy, 2017, 109: 92-102.
- [13] 王博, 吴智群. 电站风机故障智能预警技术的应用研究[J]. 热能动力工程, 2017, 32(10): 66-70.
WANG Bo, WU Zhiqun. Study of applications of the intelligent fault early warning technology for fans in power plants[J]. Journal of Engineering for Thermal Energy and Power, 2017, 32(10): 66-70.
- [14] ZAVALJEVSKI N, GROSS K C. Sensor fault detection in nuclear power plants using multivariate state estimation technique and support vector machines[C]. The Economic Theory of Invention and Innovation. Edward Elgar, 2001: 1-8.
- [15] CHENG S, PECHT M. Multivariate state estimation technique for remaining useful life prediction of electronic products[J]. Parameters, 2007: 102-107.
- [16] SAITO N. The generalized spike process, sparsity and statistical independence[J]. Mathematics, 2001, 2: 317-340.
- [17] 周浩豪, 茅大钧, 李玉珍. 基于 SSAPSO-LightGBM 的火电厂引风机故障方法[J]. 热能动力工程, 2023, 38(2): 153-160.
ZHOU Haohao, MAO Dajun, LI Yuzhen. Fault early warning method for induced draft fan in thermal power plant based on improved SSAPSO-LightGBM[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(2): 153-160.
- [18] 杨婷婷, 高乾, 李浩千, 等. 基于卷积神经网络-长短期记忆神经网络的磨煤机故障预警[J]. 热力发电, 2022, 51(10): 122-129.
YANG Tingting, GAO Qian, LI Haoqian, et al. Coal mill fault early warning technology based on CNN-LSTM network[J]. Thermal Power Generation, 2022, 51(10): 122-129.
- [19] 赵征, 丁建平. 基于深度双向门控循环神经网络的制粉系统故障预警[J]. 动力工程学报, 2023, 43(5): 598-605.
ZHAO Zheng, DING Jianping. Fault warning of pulverized system based on deep bidirectional gated recurrent neural network[J]. Journal of Chinese Society of Power Engineering, 2023, 43(5): 598-605.
- [20] 李刚, 仇晨光, 曹帅, 等. 基于稳健状态估计的设备状态预警研究[J]. 热力发电, 2020, 49(11): 1-7.
LI Gang, QIU Chenguang, CAO Shuai, et al. Early warning of equipment state based on robust state estimation[J]. Thermal Power Generation, 2020, 49(11): 1-7.
- [21] 刘双白, 朱龙飞, 仇晓智, 等. 基于加权 AAKR 算法的发电设备状态预警技术研究[J]. 热能动力工程, 2020, 35(7): 235-241.
LIU Shuangbai, ZHU Longfei, QIU Xiaozhi, et al. Study of power equipment condition early warning technology based on weighted AAKR algorithm[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(7): 235-241.
- [22] 牛玉广, 李晓斌, 张佳辉. 基于多元状态估计与自适应阈值的电站辅机故障预警[J]. 动力工程学报, 2019, 39(9): 717-724.
NIU Yuguang, LI Xiaobin, ZHANG Jiahui. Early fault warning for auxiliary equipment of power plants based on multivariate state estimation and adaptive threshold[J]. Journal of Chinese Society of Power Engineering, 2019, 39(9): 717-724.
- [23] 蔡吉磊, 茅大均, 李玉珍. 基于改进 HAC 和 MSET 的给水泵故障预警方法[J]. 热能动力工程, 2023, 38(8): 176-184.
CAI Jilei, MAO Dajun, LI Yuzhen. Feed water pump fault early warning method based on improved HAC and MSET[J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(8): 176-184.
- [24] 余兴刚, 宾谊沅, 陈文, 等. 基于改进 MSET 的一次风机故障预警及诊断方法[J]. 机电工程, 2023, 40(4): 535-541.
YU Xinggang, BIN Yiyuan, CHEN Wen, et al. Early warning and diagnosis of primary fans based on improved MSET[J]. Journal of Mechanical & Electrical Engineering, 2023, 40(4): 535-541.
- [25] 张凤丽, 潘辉, 王金江. 基于多元状态估计的热交换

- 器多参数关联预警方法[J]. 化工学报, 2022, 73(2): 814-826.
- ZHANG Fengli, PAN Hui, WANG Jinjiang. Multi-parameter correlation early warning method of heat exchanger based on multivariate state estimation[J]. CIESC Journal, 2022, 73(2): 814-826.
- [26] 胡杰, 唐静, 谢仕义. 基于实时动态基线的运行设备多元状态估计方法[J]. 热力发电, 2021, 50(2): 125-131.
- HU Jie, TANG Jing, XIE Shiyi. Multivariate state estimation technique for equipment running condition using real-time dynamic baseline[J]. Thermal Power Generation, 2021, 50(2): 125-131.
- [27] 韩万里, 茅大钧, 印琪民. 基于 PCA 和多元状态估计的引风机故障预警[J]. 热能动力工程, 2020, 35(1): 91-97.
- HAN Wanli, MAO Dajun, YIN Qimin. Induced draft fan fault warning based on PCA and multivariate state estimation technique[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(1): 91-97.
- [28] 郭鹏, 徐明, 白楠, 等. 基于 SCADA 运行数据的风电机组塔架振动建模与监测[J]. 中国电机工程学报, 2013, 33(5): 128-135.
- GUO Peng, XU Ming, BAI Nan, et al. Wind turbine tower vibration modeling and monitoring driven by SCADA data[J]. Proceedings of the CSEE, 2013, 33(5): 128-135.
- [29] 王梓齐. 基于正常行为建模的风电机组状态监测方法研究[D]. 北京: 华北电力大学, 2023: 1.
- WANG Ziqi. Research on condition monitoring method of wind turbine based on normal behavior modeling[D]. Beijing: North China Electric Power University, 2023: 1.
- [30] 吴涛, 王毅, 刘震, 等. 基于多元状态估计-层次分析法的磨煤机故障预警[J]. 热力发电, 2023, 52(5): 14-21.
- WU Tao, WANG Yi, LIU Zhen, et al. Coal mill fault warning based on multi-state estimation-analytic hierarchy process[J]. Thermal Power Generation, 2023, 52(5): 14-21.
- [31] 安吉振, 乔世超, 陈衡, 等. 基于多元状态估计和向量相似度的电站磨煤机故障智能预警研究[J]. 热力发电, 2022, 51(12): 64-71.
- AN Jizhen, QIAO Shichao, CHEN Heng, et al. Research on intelligent early warning of coal mill failure in power station based on multistate estimation and vector similarity[J]. Thermal Power Generation, 2022, 51(12): 64-71.
- [32] BARALDI P, MAIO F D, TURATI P, et al. Robust signal reconstruction for condition monitoring of industrial components via a modified Auto Associative Kernel Regression method[J]. Mechanical Systems and Signal Processing, 2015, 60(61): 29-44.

(责任编辑 杜亚勤)